



Tema 3. Árbores de clasificación e regresión

Árbore binaria:
pode ser non
binaria



- Cada nodo divide (splits) unha entrada x_i de $\mathbf{x}=(x_1,\dots,x_n)$ usando un umbral U_i . Primeiro selecciona a entrada i
- Representación como árbore (esquerda) ou como rexións no espazo de entrada (dereita)
- Fronteiras entre rexións paralelas aos eixos, definidas polos umbrais U_i

Creación de árbore de clasificación binaria

```

proc árbore( $r, \{x_{s(i)}, y_{s(i)}\}_{i=1}^M$ ) #  $r$ =nodo raíz,  $\{x_{s(i)}, y_{s(i)}\}_{i=1}^M$ =patróns de  $r$ 
  if  $\exists y$  tal que  $y_i=y$  para  $i=1..M$  # tódolos  $x_i$  da mesma clase
     $y_r=y$ ;  $r$  terminal; remata
  else
    avalía incr. entropía nodo  $r$  :  $E = -\sum_{i=1}^M P_i \log_2 P_i$ ;  $\Delta E=0$ ;  $k=1$ ;  $U=1$ 
    for  $i=1:n$  # percorre entradas
      for  $j=v_i$  #  $v_i$ =vector cos valores de característica  $i$ 
        avalía entropía  $E_{ij}$  dividindo a entrada  $x_i$  co umbral  $j$ 
        if  $E-E_{ij} > \Delta E$ ;  $\Delta E=E-E_{ij}$ ;  $k=i$ ;  $U=j$  #  $k$ =entrada;  $U$ =umbral
        end
      end
    end
     $\delta(t)=1$  se  $t=0$   $\delta(t)=0$  noutro caso
    if  $\Delta E=0$ 
       $y_r = \underset{j=1 \dots C}{\operatorname{argmax}} \left\{ \sum_{i=1}^M \delta(j - y_{s(i)}) \right\}$ ;  $r$  terminal; remata
    else
      crea nodo  $r_e$ ; árbore( $r_e, \{x_{ij}, y_i : x_{ik} < U\}$ ) # recursivo nodo esquerdo
      crea nodo  $r_d$ ; árbore( $r_d, \{x_i, y_i : x_{ik} \geq U\}$ ) # recursivo nodo dereito
    endif
  end if
end proc

```

Asocia o nodo terminal á clase máis poboada

Entrenamento recursivo dende arriba (nodo raíz) cara abaixo na árbore

Saída da árbore de clasificación

- Sexa R o nº de rexións $R_1..R_R$ no espazo de entrada; $I_i(\mathbf{x})=1$ se $\mathbf{x} \in R_i$ e $I_i(\mathbf{x})=0$ noutro caso; R_i a rexión i -ésima, con $i=1..R$
- A saída da árbore é: $z(\mathbf{x}) = \sum_{i=1}^R y_i I_i(\mathbf{x})$
- Na práctica, o procedemento que se segue é:
 - 1) O patrón de teste $\mathbf{x}$ preséntase ao nodo raíz r , que divide a entrada k con umbral U e efectúase o teste $x_k > U$
 - 2) Se $x_k < U$, repítese o proceso co nodo r_e (fillo esquerdo)
 - 3) Se $x_k \geq U$, repítese o proceso co nodo r_d (fillo dereito)
 - 4) O proceso repítese ata que se acada un nodo r terminal
 - 5) A saída da árbore é a etiqueta y_r que durante o entrenamento foi a clase maioritaria entre os patróns deste nodo terminal r

Selección da entrada a dividir

- **Entropía** E : avalía en que medida os patróns de entrenamento que chegan a un nodo teñen distintas clases
- Sexan: N_i =nº patróns de clase i no nodo; N =nº patróns do nodo; $P_i=N_i/N$, a proporción de patróns da clase i no nodo:

$$E = - \sum_{i=1}^C P_i \log_2 P_i$$

- A mellor entrada j e umbral U : as que máis reducen a entropía E :

$$(j, U) = \underset{1 \leq i \leq n; k \in \mathbf{v}_i}{\operatorname{argmax}} \{ \Delta E_{ik} \} \quad \Delta E_{ik} = E - P E_{ik}^e - (1 - P) E_{ik}^d$$

- $\mathbf{v}_i$ =valores da entrada x_i para os patróns do nodo
- $P=N_e/N$, $N_e(i,k)$ =nº de patróns asignados ao nodo esquerdo (e)
- E_{ik}^e , E_{ik}^d : entropías dos nodos esquerdo e dereito (entrada x_i e umbral k)

Medidas de erro alternativas á entropía

- **Índice de Gini:** $G = 1 - \sum_{i=1}^C P_i^2$: erro medio se seleccionas a clase aleatoriamente entre as presentes no nodo
- **Erro de clasificación:** $J = 1 - \max_{1 \leq i \leq C} \{P_i\}$
 $J=0$ so se $\exists m$ con $P_m=1$, i.e., se $N_m=1$ e $N_i=0$ para $i \neq m$ (tódolos patróns que chegan ao nodo son da mesma clase)
- Os criterios de parada e podado inflúen máis nos resultados que medida de erro usada
- Unha **entrada continua** discretízase en $S=T+1$ intervalos de lonxitudes iguais ou distintas usando unha serie de umbrais $\{t_i\}_{i=1}^T$. Cada nodo divide en S nodos
- Os umbrais t_i fíxanse: 1) equiespazados no rango de valores; ou 2) maximizando a varianza de cada intervalo neste rango

Criterios de parada na creación de nodos

1) O erro de validación deixa de reducirse

2) A mellor división ten $\Delta E < \Delta E_0$

3) Non se engaden máis nodos

4) Ao acadar un nº máximo de nodos

- As árbores tenden á sobreaprendizaxe

- A árbore pode non ser binaria usando un factor de división $B > 2$

- Selecciónase os valores (i,U) que maximizan este incremento da entropía.

- P_r = fracción de patróns do nodo asignados ao fillo r

- Obxectivo: árbore simple e compacta con poucos nodos

$$\Delta E = \frac{E - \sum_{i=1}^B P_i E_i}{-\sum_{i=1}^B P_i \log_2 P_i}$$


Regularización e podado


- **Regularización:** consiste en ponderar a suma das entropías dos M nodos terminais e o tamaño T da árbore (n° nodos ou enlaces)

$$\sum_{i=1}^M E_i + \lambda T$$

entropía dos M nodos terminais
sobre o conxunto de entrenamento

tamaño da árbore

- **Podado** (pruning): a árbore crece ata acadar o n° máximo de nodos, e logo suprímense pares de nodos terminais se así diminúe a entropía
- Sitúa os nodos terminais en varios niveis: árbores desequilibradas
- Nodos con tódolos fillos terminais pódense substituír unha subárbore por un nodo terminal
- Non está garantido que se minimice a entropía porque cada nodo usa unha soa entrada
- O podado non garante que se acade a árbore mínima



<https://www.cs.cmu.edu/~bhiksha/courses/10-601/decisiontrees/>

Árbores de regresión (I)

- En problemas de regresión, a entrada j a dividir e o umbral U da división selecciónanse de modo que se minimice a suma de erros cadráticos (SSE)
- Sexan $A_1(i,k)=\{l : x_{li}<k\}$ e $A_2(i,k)=\{l : x_{li}\geq k\}$: selecciónase (j,U) como:

$$(j, U) = \underset{1 \leq i \leq n; k \in \mathbf{v}_i}{\operatorname{argmin}} \left\{ \sum_{m \in A_1} (y_m - z_1)^2 + \sum_{m \in A_2} (y_m - z_2)^2 \right\}$$

$\mathbf{v}_i$: vector cos valores de x_i

Predicción do nodo: media das saídas asociadas aos patróns deste nodo

$$z_p(i, k) = \frac{1}{N_p} \sum_{q \in A_p(i, k)} y_q, p = 1, 2$$

N_p é o nº de elementos de $A_p(i, k)$

- Cando se crea un nodo terminal r , a súa saída y_r é o valor medio das saídas desexadas para os patróns de entrenamiento $\{\mathbf{x}_{s(i)}, y_{s(i)}\}$, con $i=1..M_r$ que chegan a este nodo r :

$$y_r = \frac{1}{M_r} \sum_{i=1}^{M_r} y_{s(i)}$$

Árbores de regresión (II)

- A saída da árbore para un patrón de teste $\mathbf{x}$ é:

$$z(\mathbf{x}) = \sum_{i=1}^R y_i I_i(\mathbf{x})$$

- $R_1 \dots R_R$ son as rexións nas que a árbore divide ao espazo de entrada, e R é o nº de rexións
- $I_i(\mathbf{x}) = 1$ se $\mathbf{x} \in R_i$ e $I_i(\mathbf{x}) = 0$ noutro caso
- Na práctica, o patrón $\mathbf{x}$ preséntase ao nodo raíz r e selecciónase o nodo fillo ao cal ir comparando a entrada x_k e o umbral U de r
- Se $x_k < U$ (resp. $x_k \geq U$), repítese o proceso con r_e (resp. r_d), fillo esquerdo (resp. dereito)
- O proceso repítese ata que se acada un nodo r terminal
- A saída $y(\mathbf{x})$ é y_r , a media das saídas desexadas para os patróns de entrenamiento asociados ao nodo terminal r

Vantaxes e inconvenientes

- ✓ Modelos de **caixa branca**: dan unha explicación do coñecemento aprendido (regras), e explican a saída predita
- ✓ Valen para entradas continuas e discretas: non requiren variábeis indicadoras (dummy)
- ✓ Realizan unha selección de entradas porque descartan as entradas non importantes, que non se dividen
- ✓ Son robustas con datos colineares (entradas dependentes)
- ✓ Funcionan ben con datos grandes
- ✗ Pouco estables: pequenos cambios no conxunto de entrenamento provocan grandes cambios na árbore
- ✗ Baseados en heurísticas: poden non acadar elevada precisión
- ✗ Poden xerar árbores moi grandes de difícil comprensión
- ✗ Isto pode provocar **sobreaprendizaxe**

Implementacións

- En Octave facemos unha implementación propia. En Matlab, require a Statistical and Machine Learning Toolbox

	Matlab	Python	R	Weka-Java
Árbore de clasificación	fitctree	tree/DecisionTreeClassifier	rpart/ rpart	weka.classifiers.trees.J48
Árbore de regresión	fitrtree	tree/DecisionTreeRegressor		weka.classifiers.trees.J48